

ISSN 1330-7142
UDK = 631.42.001

ANALIZA POGODNOSTI ZEMLJIŠNIH RESURSA ISTOČNE HRVATSKE FUNKCIJSKIM MODELOM

V. Vukadinović ⁽¹⁾, Blaženka Bertić ⁽¹⁾, B. Đurđević ⁽¹⁾, Vesna Vukadinović ⁽¹⁾, Irena Jug ⁽¹⁾, Ž. Kraljićak ⁽²⁾

Izvorni znanstveni članak
Original scientific paper

SAŽETAK

Na području istočne Hrvatske analizirano je ukupno 17.405 uzoraka tla (2003.-2009. god.). Cilj ovoga rada je procjena pogodnosti zemljišta za usjeve, tj. kvantitativno opisati kakvoću određenoga tla i prikazati nedostatke unutar jednoga sustava korištenja tla. U radu je opisan matematički model koji, uz pomoć skor funkcija, procjenjuje pojedine indikatore pogodnosti zemljišta. Matematički model procjene pogodnosti tla za usjeve, podržan GIS-om, pokazao se brzim i efikasnim, uz dovoljnu pouzdanost. Korištenjem GIS alata moguće je vizualizirati pogodnost i prikazati je na različitim podlogama, tj. kartama, a geostatističkom analizom krigingom omogućena je rajonizacija proizvodnoga područja temeljem kvantitativne ocjene pogodnosti za usjeve.

Ključne riječi: *kompjuterski model, kriging, procjena pogodnosti tla za usjeve*

UVOD

Plodnost tla može se procijeniti vrednovanjem njegovih specifičnih funkcija koje kvantificiraju biljnu produktivnost, a utječu i na okoliš i na zdravlje ljudi. Karlen i sur. (1997.) i Pierce i Larson (1993.) pojednostavljeno definiraju plodnost tla kao njegov „kapacitet za funkcioniranje“, a on može biti degradiran primjenom neodgovarajuće agrotehnike u ratarskoj ili stočarskoj proizvodnji (odsustvo primjene stajnjaka, navodnjavanje vodom loše kakvoće, neadekvatna i pretjerana gnojdba, neadekvatna primjena pesticida, gradskog ili industrijskog otpada ili drugih toksičnih nusprodukata i dr.).

Znanstvena procjena produktivnosti tla temelji se na utvrđivanju indikatora plodnosti koji moraju biti osjetljivi, pouzdani, reproducibilni, a dobro detektiraju promjene fizikalnih, kemijskih i bioloških svojstava i procesa u tlu te njihove interakcije (Mausbach i Tugel, 1997.). Konvencionalne metode razvrstavaju tla u bonitetne klase, što je nedovoljno, jer kapacitet produkcije tla zavisi o složenome kompleksu i interakciji velikoga broja ne samo biljno-proizvodnih činitelja. Zapravo, stvarna produktivnost tla zavisi i o motiviranosti proizvođača za proizvodni rizik, njihovome znanju, potrebi tržišta, ekonomskoj politici države te socijalnoj i kulturnoj

tradiciji. Zato dobra procjena proizvodnoga potencijala nekoga tla, pored agroekoloških svojstava, uključuje i kvantifikaciju načina njegove uporabe.

Gnojdbena preporuka mora imati za podlogu fizikalno-kemijske podatke analize tla, a izračun potrebne doze mora uvažavati profitabilnost, planirani, odnosno realno mogući prinos, specifične potrebe biljne vrste i potencijal plodnosti tla. Svaka improvizacija, uključujući subjektivnu vizualnu procjenu, najčešće rezultira smanjivanjem prinosa i kakvoće usjeva, odnosno profita.

U rješavanju te problematike može se očekivati brz napredak samo uz širu primjenu kemijskih analiza tla, kompjuterske tehnologije, korištenjem interpretacijskih baza podataka o svim relevantnim svojstvima tla te bilanciranjem hraniva ovisno o različitim agrološkim uvjetima proizvodnje.

U radu je opisan matematički model koji koristi skor funkcije procjene pojedinih indikatora pogodnosti zemlji-

(1) Prof.dr.sc. Vladimir Vukadinović (vladimir.vukadinovic@pfos.hr), prof. dr. sc. Blaženka Bertić, dr.sc. Boris Đurđević, doc.dr.sc. Vesna Vukadinović, doc.dr.sc. Irena Jug - Sveučilište Josipa Jurja Strossmayera u Osijeku, Poljoprivredni fakultet u Osijeku, Trg Svetog Trojstva 3, 31000 Osijek, (2) Željko Kraljićak, dipl. ing. - Osječko-baranjska Županija, Upravni odjel za poljoprivredu i gospodarstvo, Trg Ante Starčevića 2, 31000 Osijek

šta, čija je primjena započeta na području Slavonije i Baranje prije 15-ak godina (Vukadinović i sur., 1992.) i sada je u fazi intenzivne primjene. Model je podržan sofisticiranim kompjutorskim programom (Vukadinović, 2005.), koristi ulaznu relacijsku bazu za unos podataka o tlu, biljnoj proizvodnji, uređenosti zemljišta, primjeni agrotehnike, fizikalno-kemijskim svojstvima tla i dr., a rezultati kompjutorske obrade tih podataka tiskaju se kao preporuka gnojidbe. Model uključuje praćenje i tumačenje klime, tla, vegetacije i drugih aspekata zemljišta u smislu zahtjeva za alternativne oblike korištenja zemljišnih resursa unutar relevantnoga fizičkoga, ekonomskoga i socijalnoga konteksta. U dodatku gnojdbene preporuke su savjeti dobre poljoprivredne prakse, odnosno prijedlog agrotehničkih mjera za popravke zemljišta te potrebi i načinu eliminacije limitirajućih faktora. Svi podaci automatski se prenose u izlaznu relacijsku bazu za vizualizaciju i geostatističku analizu, uključujući i predikciju GIS alatima.

MATERIJAL I METODE

U okviru projekta "Analiza tla kao temelj racionalizacije gnojidbe" na području Osječko-baranjske županije (2003.-2009. godine) analitički je obrađeno 17.405 uzorka tla, od kojih 2/3 uzorka pripadaju Osječko-baranjskoj županiji. U Zavodu za kemiju, biologiju i fiziku tla Poljoprivrednoga fakulteta u Osijeku razrađena je strategija uzimanja uzoraka i njihove analize te izrađen sustav baze podataka podržane GIS-om i kompjutorskim programima za izdavanje gnojdbenih preporuka s potrebnim objašnjenjima. Organizirano uzimanje uzoraka na terenu i njihovu pripremu te laboratorijsku obradu provodilo je više laboratorija i dvije šećerane s područja istočne Hrvatske.

Uzorci tla uzimani su sondom i to 25 uboda do 30 cm na 3-5 ha (ovisno o veličini parcele i homogenosti tla), geografska pozicija parcele i njena nadmorska visina određeni su GPS-om, a potrebni podaci o vlasništvu, predkulturi i uređenosti zemljišta prikupljeni su na terenu prema standardnom anketnom listu za proračun gnojidbe. Priprema uzoraka i njihova analiza u laboratoriji provedena je standardnim postupcima (Vukadinović i Bertić, 1989.) te su svi podaci uneseni u "ulaznu bazu" za proračun potrebe u gnojdbi ALRxp kompjutorskim programom (Vukadinović i sur., 2001.a i 2001.b).

Gnojdbene preporuke po predloženoj modelu temelje se na fizikalno-kemijskoj analizi tla, prinosima ostvarenim u prethodnoj proizvodnji, organskoj gnojdbi i drugim svojstvima tla prikupljenih uvidom na terenu kod uzorkovanja. Kalkulacija potrebne doze gnojiva uvažava profitabilnost, planirani (realno mogući) prinos, specifične potrebe biljne vrste i potencijal plodnosti tla. ALRxp kalkulator vrlo je sofisticiran program, koji jasnim objašnjenjima pokušava umanjiti nepovjerenje farmera

prema kompjutorskom izdavanju gnojdbenih preporuka, čija se vjerodostojnost mora u primjeni dokazati reakcijom prinosa usjeva na preporučenu gnojidbu, dakako uz porast profita. Stoga se neprestano unapređuje ALRxp program za proračun gnojidbe uz povećanje broja mjerljivih indikatora plodnosti, a korisniku sve detaljnije obrazlaže gnojdbena doza, raspodjela gnojiva, predlaže mjere eliminacije limitirajućih faktora i uz bilancu hraniva te procjenu relativne pogodnosti tla za usjeve predlaže gnojidba za ciklus plodosmjene (rotacija do 6 usjeva).

Model koristi nelinearne skor funkcije (Đurđević, 2010). Pogodnost zemljišta za usjeve procjenjuje se pomoću 7 analitičkih i 15 dopunskih indikatora produktivnosti: AL- P_2O_5 , AL- K_2O , pH-KCl, pH- H_2O , Hy (hidrolitička kiselost), sadržaj humusa i karbonata (%), dok se od dopunskih indikatora kationski izmjenjivački kompleks (KIK) i gustoća tla procjenjuju na temelju empirijskih modela, a u procjenu su još uključena organska gnojidba, prinos predkulture, žetveni ostaci, prosječna godišnja temperatura, prosječna godišnja količina oborina, biogenost tla, potencijal NP mineralizacije organske tvari, tekstura, nagib, uređenost tla, razina agrotehnike i zaštite usjeva te procjena relativne pogodnosti tla za usjeve. Vrlo slično tome modelu, kako navode Seybold i sur., (2005.) za potrebe Nacionalne baze podataka o tlu SAD-a, koriste se prediktivni, ali linearni modeli, pri čemu se homogene grupe tala izdvajaju prema sadržaju organske tvari u tlu, pH, mineraloškoj klasi i KIK-u. Baza podataka koju koristi United States Department of Agriculture (USDA, 1995.) za interpretaciju koristi preko 25 fizikalnih i kemijskih svojstava tla, koji se, pomoću ArcView programa, mogu vizualizirati za svaku zemljišnu jedinicu.

REZULTATI I RASPRAVA

Osnovni statistički pokazatelji analize tla (Tablica 1.) prikazuju prosječne vrijednosti i variranja indikatora produktivnosti zemljišta istočne Hrvatske, koja su posljedica na tako velikome proizvodnome području, zbog razlike u pedološkim, geomorfološkim i klimatskim svojstvima. Općenito, od istoka prema zapadu raste količina oborina (č30%), kao i nadmorska visina (od 80 m uz Dunav pa sve do blizu 1000 m na Papuku i Psunju), a tla su sve kiseliša, što, uz različiti matični supstrat i različite tipove tala (kao i promjenu klimaks vegetacije), rezultira bitno drugačijim agroekološkim uvjetima poljoprivredne proizvodnje.

Utvrđene su izrazito jake korelacijske veze (Tablica 2.) između pojedinih indikatora produktivnosti tla. Negativna je veza između pH_{KCl} i Hy očekivana, a visoki koeficijent korelacije ($r = -0,930^{+++}$) pokazuje da vrlo mali broj uzoraka odstupa od te pravilnosti. Između pH_{KCl} i humusa ostvarena je značajna pozitivna korelacija ($r = 0,363^{+++}$), vrlo vjerojatno prouzročena slabijom dekompozicijom humusa u redukcijskim uvjetima.

Tablica 1. Agrokemijski podaci za procjenu relativne pogodnosti zemljišta (RP %) istočne Hrvatske za usjeve*Table 1. Agrochemical data for crops relative soil suitability evaluation (RP %) of eastern part of Croatia*

Statistika <i>Statistics</i>	pH-KCl	pH-H ₂ O	Humus (%)	Hy	KIK	AL-P ₂ O ₅	AL-K ₂ O	ρ g/cm ³	RP %
				cmol ⁽⁺⁾ .kg ⁻¹ tla/ <i>soil</i>	mg/100 g tla/ <i>soil</i>				
n	17405	17405	17405	17405	17405	17405	17405	17405	17405
Prosjek <i>mean</i>	5,61	6,50	2,13	2,59	13,39	19,27	23,85	1,42	56,23
Sd	1,20	1,10	0,75	2,41	2,13	10,71	8,17	0,09	20,83
Kv%	21,37	16,99	35,18	93,07	15,89	55,57	34,26	6,69	37,04
min	3,37	3,94	0,32	0,00	9,49	0,40	3,60	1,20	0,00
max	8,20	9,30	6,92	13,99	26,05	50,00	50,00	1,75	83,04

Tablica 2. Korelacije (linearne) između analitičkih indikatora pogodnosti tla*Table 2. Correlations (linear) between the analytical indicators of soil suitability*

	pH_KCl	pH_HOH	Humus	AL-P ₂ O ₅	AL-K ₂ O	KIK	ρ	Hy	RP%
pH_KCl	1								
pH_HOH	0,963	1							
Humus	0,363	0,364	1						
AL-P ₂ O ₅	0,195	0,138	0,151	1					
AL-K ₂ O	-0,016	-0,081	0,053	0,551	1				
KIK	0,636	0,625	0,930	0,189	0,036	1			
ρ	-0,072	0,007	-0,091	-0,031	-0,061	-0,080	1		
Hy	-0,930	-0,911	-0,314	-0,147	0,061	-0,586	0,029	1	
RP%	0,816	0,814	0,426	0,238	0,061	0,659	0	-0,808	1

Visoka i pozitivna korelacija između AL-P₂O₅ i AL-K₂O ($r = 0,551^{+++}$) tipična je za antropogeni utjecaj, odnosno posljedica je dugogodišnje primjene kompleksnih mineralnih gnojiva na poljoprivrednim površinama. Prema istraživanjima Oorts i sur. (2007.), najveći utjecaj na kvalitetu tla, posebice KIK, ima organska tvar u tlu, a humus i pH objašnjavaju više od 85 % varijacija KIK-a u tlu. Sličnu korelaciju pokazuje i ovo istraživanje pa je tako utvrđena vrlo signifikantna korelacija između relativne pogodnosti tla i humusa ($r = 0,426^{+++}$), odnosno RP% i KIK-a ($r = 0,659^{+++}$), a nije bilo korelacije između gustoće tla i relativne pogodnosti, što može biti i posljedica loše obučenosti uzorkivača, odnosno pogrešne primjene "feel metode".

Relativna pogodnost ispitivanih površina u prosjeku je 56,03 %, uz relativno visok koeficijent variranja (Kv% = 37,04). Analizom multiple regresije utvrđeno je da relativna pogodnost tla za usjeve visoko signifikantno ovisi o svim uključenim indikatorima plodnosti ($R^2 = 0,993^{+++}$ za 17.405 opservacije):

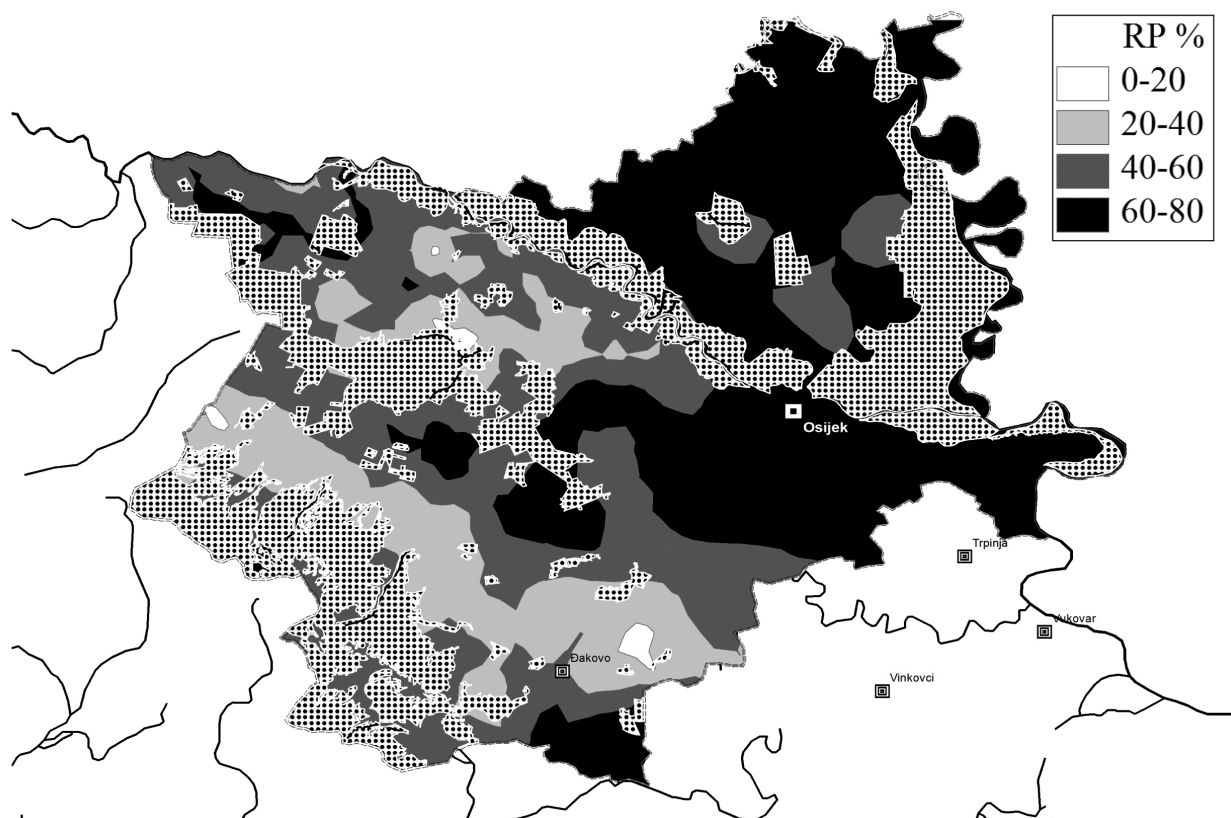
$$RP\% = -57,386 + pH\text{-}KCl \times 0,127 + Humus \times 0,172 + AL\text{-}P_2O_5 \times 0,199 + AL\text{-}K_2O \times 0,211 + \rho \times 0,214 + KIK \times 0,287 + Hy \times 0,225$$

Za geostatističku analizu pogodnosti zemljišta u istočnoj Hrvatskoj izabran je samo prostor Osječko-baranjske županije, jer je najgušće pokriven uzorcima. Proračun površine Osječko-baranjske županije GIS-om neznatno se razlikuje od službenoga podatka (413.461 ha prema službenim 415.500 ha).

Prema podacima o relativnoj pogodnosti (Tablica 3.), u Osječko-baranjskoj županiji vrlo malo je površina privremeno i trajno nepogodno za uzgoj usjeva (č56.000 ha). Njihova neplodnost izazvana je najviše ekstremno kiselim reakcijom (pH-KCl ≤ 3,7) ili vrlo niskim sadržajem organske tvari tla (humus ≤ 0,5%). Relativna pogodnost tla za usjeve smanjuje se od istoka prema zapadu Osječko-baranjske županije, što jasno pokazuje procjena pogodnosti opisanim funkcijskim modelom (Slika 1.).

Tablica 3. Relativna i FAO pogodnost zemljišta za usjeve Osječko-baranjske županije*Table 3. Relative and FAO soil suitability for crops in Osijek-Baranja County*

	Klasa pogodnosti Suitability class	RP %	ha	Bez šumskih površina (ha) Without forest area (ha)
Nepogodno Unsuitability	N2	0 - 20	2.331,66	1.917,84
	N1	20 - 40	68.110,83	54.293,99
Pogodno Suitability	S3	40 - 60	159.107,70	102.851,50
	S2	60 - 80	183.910,36	142.393,37
	S1	80 - 100	0	0
Županija ha – County ha			413.460,58	301.456,71



Slika 1. Kriging relativne pogodnosti zemljišta Osječko-baranjske županije

Figure 1. Soil suitability kriging of Osijek-Baranja County

ZAKLJUČAK

Na temelju rezultata kompjutorskoga, funkcijskoga modela procjene pogodnosti zemljišta za usjeve i geostatističke analize podataka na području istočne Hrvatske, može se ukratko zaključiti:

1) U razdoblju 2003.-2009. godine na području istočne Hrvatske analitički je obrađeno 17405 uzorka tla, od kojih $\frac{2}{3}$ pripadaju Osječko-baranjskoj županiji. Prosječna relativna plodnost (RP%) je osrednja (56,23%) ili prema FAO klasifikaciji S3.

2) Utvrđene su značajne korelacijske veze između pojedinih indikatora produktivnosti tla: negativna veza između pH_{KCl} i H_y ($r = -0,930^{+++}$), pozitivna između pH_{KCl} i humusa ($r = 0,363^{+++}$), kao i između $AL-P_2O_5$ i $AL-K_2O$ ($r = 0,551^{+++}$), koja je, vjerojatno, rezultat antropogenih aktivnosti.

3) Analizom multiple regresije ($R = 0,993^{+++}$) utvrđen je parcijalni utjecaj svih analitičkih indikatora pogodnosti za usjeve prema sljedećem izrazu: $RP\% = -57,386 + pH_{KCl} \times 0,127 + Humus \times 0,172 + AL-P_2O_5 \times 0,199 + AL-K_2O \times 0,211 + p \times 0,214 + KIK \times 0,287 + H_y \times 0,225$

4) Krigingom površine Osječko-baranjske županije utvrđen je sljedeći prostorni udio: 56.212 ha (18,65%) nije pogodno za uzgoj usjeva, 102.852 ha (34,12%) ograničeno je plodno, a 142.393 ha ili 47,24% površina dobre je plodnosti.

LITERATURA

1. Đurđević B. (2010.): Ekspertni model procjene pogodnosti zemljišta za usjeve. Doktorska disertacija, Osijek, Poljoprivredni fakultet.
2. Karlen D.L., Mausbach M. J., Doran J.W., Clinem R.G., Harris R. F. and Schuman G. E. (1997): Soil quality: A concept, definition, and framework for evaluation. Soil Sci. Soc. Am. J. 61:4-10.
3. Malvić T. (2005.): Kriging, geostatistička interpolacijska metoda. 2. izdanje, Zagreb, http://www.geologija.hr/pdf/Kriging_2.izd..pdf.
4. Mausbach M.J., Tugel A. (1997): Soil quality - A multitude of approaches. Kearney Foundation Symposium, Berkeley, California, March 25, 1997.
5. Miller G. (2002.): The Iowa Soil Properties and Interpretation Database (ISPAID). Iowa State University, http://extension.agron.iastate.edu/soils/pdfs/ISPAID_73man_Final.pdf
6. Pierce F.J., W.E. Larson (1993): Developing criteria to evaluate sustainable land management. p. 7-14. In: J. M. Kimble (ed), Proceedings of the Eighth International Soil Management Workshop: Utilization of Soil survey Information for Sustainable Land Use, May 3, 1993. USDA Soil Conservation Service, National Soil Survey Center, Lincoln, NE.
7. Seybold C.A., Grossman R.B., Reinsch, T.G. (2005): Predicting Cation Exchange Capacity for Soil Survey Using Linear Models. Soil Sci Soc Am J 69: 856-863

8. United States Department of Agriculture (USDA) (1995): Soil Survey Geographic (SSURGO) Data Base. <http://soildatamart.nrcs.usda.gov/documents/SSURGODataPackagingandUse.pdf>
9. Vukadinović, V., Lončarić Z. (1998.): Ishrana bilja- Poljoprivredni fakultet u Osijeku, udžbenik, str. 294.
10. Vukadinović, V., Bertić Blaženka (1989.): Praktikum iz agrokemije i ishrane bilja. Poljoprivredni fakultet u Osijeku, 126 str.
11. Vukadinović V., Bertić Blaženka i Kovačević V. (1992.): Kvantifikacija produktivnosti tala Slavonije i Baranje. Zbornik radova Znanstveno-stručnog skupa "Obnova i razvoj istočne Hrvatske", Bizovac, 23-24.06.
12. Vukadinović, V., Bertić Blaženka, Vukadinović Vesna, Rastija, D. (2005): Soil analyses and computer model for crop fertilization. Program and Abstract Book of 9th International Symposium on Soil and Plant Analysis: Soil, Plant and Water Analysis: Quality Analytical Tools for an Era of Ecological Awareness. Etchevers, J.D., Hidalgo, C. (ed.). Soil and Plant Analysis Council. Cancun. Mexico. 2005: 36.
13. Vukadinović, V., Lončarić, Z., Teklić Tihana (1997): Agrochemical Mapping of the Soil Fertility with Graphic Display of Fertilization Recommendations. Proceedings of the 19th International Conference on Information Technology Interfaces (ITI 97), University Computing Centre, Zagreb, 75-79.
14. Vukadinović, V., Lončarić, Z., Bertić, Blaženka, Teklić Tihana (2001): AL-calculator for crop fertilization recommendation "on line". Proceedings: Fertilizer, Food Security and Environmental Protection. Peking 2001: 249-250.

ANALYSIS OF LAND RESOURCES SUITABILITY BY FUNCTIONAL MODEL IN EASTERN CROATIA REGION

SUMMARY

A total of 17405 soil samples (2003rd-2009th years) were analyzed in the eastern part of Croatia. The aim of this paper is to assess land suitability for crops i.e. to describe quantitatively land quality and indicate disadvantages of land using system in investigated area. The described mathematical model uses score functions for estimating indicators of soil suitability. Soil suitability assessment computer model for crops, supported by GIS, proved to be fast, efficient and enough reliable. Using GIS tool it is possible to visualize land suitability and present it in different cartographic bases such as maps whereas using geostatistical method – kriging enables to provide regionalization of production area based on quantitative assessment of land suitability for crops.

Key-words: computer model, kriging, soil suitability for crops

(Received on 23 February 2011; accepted on 16 May 2011 - *Primljeno 23. veljače 2011.; prihvaćeno 16. svibnja 2011.*)